

每周工作汇报

姓名	侯宇轩	开始日期	2018.11.7	结束日期	2018.11.12
----	-----	------	-----------	------	------------

1. 本周任务与计划

1.1 研究任务

阅读蔡老师新布置的论文：PDE-Net: Learning PDEs from Data，学习其中的方法，思考如何用其对 level-set 进行改进，来应用在神经纤维瘤分割上。

对之前的深度学习肝脏配准工作进行调整。

2. 本周工作概要

2.1 当前的进展

本周由于临近考试周，未阅读代码。不过本周在写人工智能导论课程论文时，对 MICCAI 2017-2018 的医学图像配准工作进行了综述：

MICCAI 2017-2018 医学图像配准方法

综述

11821011 侯宇轩


1. MICCAI 介绍

MICCAI 的全称是 Medical Image Computing and Computer-Assisted Intervention，是计算机影像处理计算（MIC）以及计算机辅助介入（CAI）两个领域的综合性会议。MIC 中包含的课题包括配准、机器学习、图像分割、传统 CAD（计算机辅助检测）以及临床和生物学应用。CAI 集中在介入部分，包括追踪和导航、介入式影像、医用机器人等等，是医疗影像领域的顶级会议。

2. 医学图像配准介绍

图像配准是医学人工智能中的难题。

配准指找出一个固定图像 (fixed image, F) 与一个变换图像 (Moving image, M) 之间的对应关系 (Vector field), 并将变换图像向尽量与固定图像相似的方向转变。医学图像配准主要解决对相同组织/部位的不同扫描数据的对应问题。一般 CT 扫描要向病人血管中注射造影剂以便显像, 造影剂在体内的分布不同, CT 图像中增强 (高亮) 的部分也不同。以肝脏 CT 增强扫描为例, 一般分为动脉期(Arterial)、门静脉期 (Portal) 和延迟期 (Delayed) 三期图像。下图是一个例子, 明显可以看到箭头部分 (肿瘤) 的亮度在不同的增强期内表现不同。



A:平扫 B:动脉期 C:门静脉期 D:延迟期

显然, 医学图像的配准一般是非刚性的、可变形 (Deformable) 的, 用于消除病人呼吸、心脏跳动等等引起的形变。

3.MICCAI 2017-2018 医学图像配准论文介绍

此两年的 MICCAI 的医学图像配准主要分为以下几个方面:

3.1 神经网络法学习形变向量场（监督学习）

3.1.1 Sokooti H, Vos B D, Berendsen F, et al. Nonrigid Image Registration Using Multi-scale 3D Convolutional Neural Networks (MICCAI 2017)

数据:

本文使用 SPREAD 数据，含有 19 对 3D 胸部 CT 图像，病人年龄为 49~78 不等。每位病人由 baseline 数据和 30 天 follow-up 数据组成。每对 CT 图像有 100 个半自动选取的 landmark。

介绍:

本文使用了端到端的三维网络，称为 RegNet，用于预测图像之间的 DVF（Displacement vector field）。它使用的是监督学习方法：在训练阶段，对于一个训练所用 patch，随机选取一些点作为 landmark，调整不同参数对其进行某一个方向的形变，然后使用高斯核将图像进行平滑，并将形变对应的 DVF 保存下来。使用固定图像(Fixed image, F)、变换图像(Moving image, M)作为输入，对应的变化向量场 DVF 作为训练的标签，进行监督学习。




Fig. 1. RegNet design.

测试结果发现本文方法与单精度 B 样条配准方法更优，同时也接近多精度(multi-resolution)B 样条方法。本文的主要优点是可以使用训练好的神经网络代替原始的迭代法预测配准的向量场 DVF。

本文的一个弱点是训练数据十分庞大，仅仅 19 个 case，作者就生成了 252,000 个训练样本，过拟合的危险较大。

3.1.2 Marc-Michel Rohé, Datar M, Heimann T, et al. SVF-Net: Learning Deformable Image Registration Using Shape Matching (MICCAI 2017)

数据:

心脏数据集，想要做的是不同病人之间的配准，共 187 个舒张末期的心脏 CT 数据。使用一种数据驱动的方法分割了心肌，并由专家控制了质量。输入尺寸 64*64*16。

介绍:

通过有监督的学习方法，预测 Stationay Velocity Fields(SVF) 来配准。我们可以认为此处的 SVF 与上一文章中的 DVF 均代表图像之间的变换向量场有相似之处，区别是 DVF 是之直接的变换向量，而 SVF 是速度场。下面是 SVF 的一个例子（红色放射线）。




Fig. 1. Example of a reference deformation SVF (red vector field scaled at 0.3) computed from two segmented surfaces. The moving image is shown with the segmentation of the myocardium of the fixed (orange) and moving (blue) images. (Left): Short-axis view. (Right): Longitudinal view.

本文使用三维的全卷积神经网络。输入原始图像（三维的两张图像，固定图像与变换图像），输出的是 SVF（三维的向量场），将输出与实际 SVF 的差值用作网络的损失，进行监督学习（SVF 即是标签）。

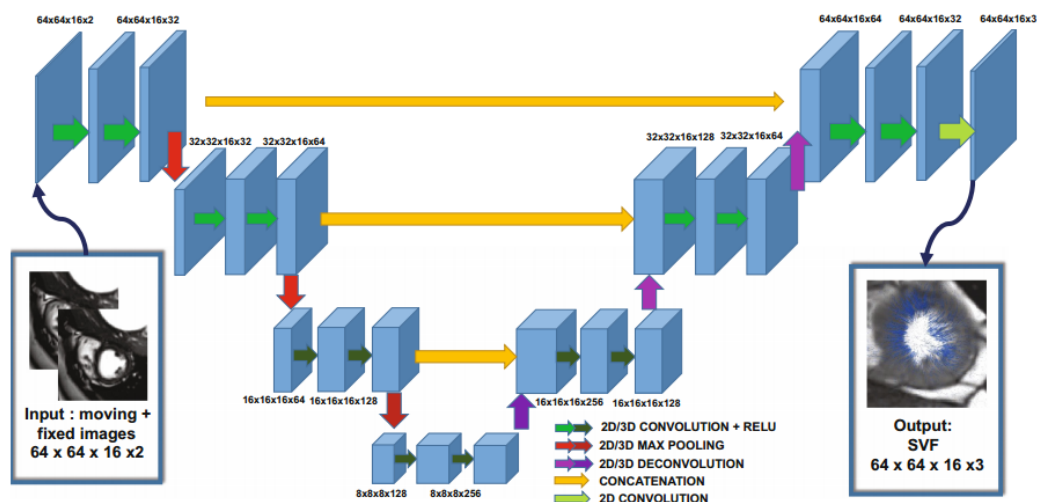
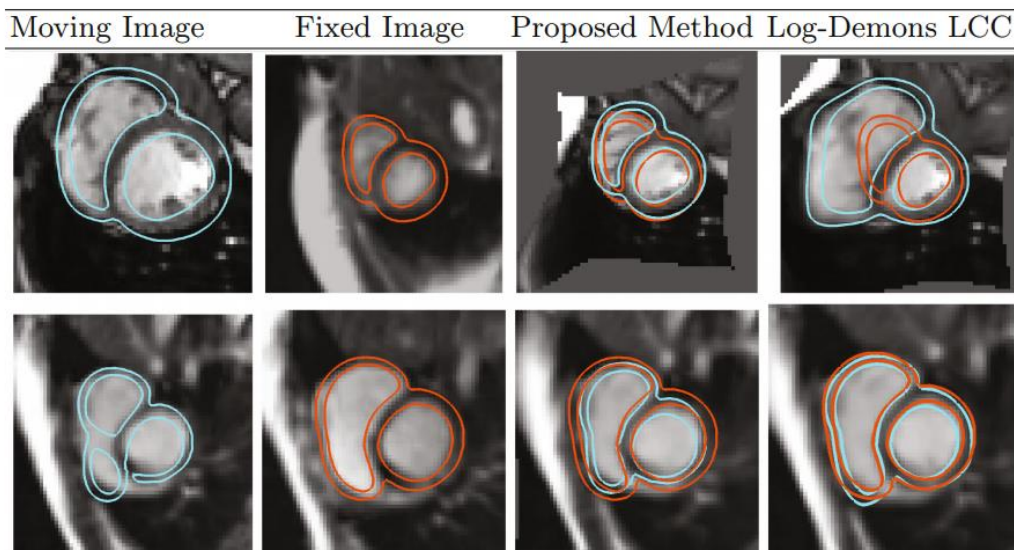


Fig. 2. Fully convolutional neural networks architecture for 3D registration.

这里的网络结构是标准的 U-net 结构。如上图，U-net 是一种 U 型全卷积网络，分为左侧的收缩路径和右侧的舒张路径两部分。左侧由卷积与 pooling 组成，图像大小不断减半，通道数不断加倍；右侧由对称的卷积和上采样组成，图像大小不断加倍，通道数不断减半，整个呈现一个 U 型的特征。U-net 的一个主要特征是在收缩路径与舒张路径之间存在直接连接，将左侧数据同右侧同级数据进行拼接（concat）后再输入卷积。这样同时提取左、右路径的特征，相当于同时提取粗粒度和细粒度的特征。U-net 被发现比较适合于医学图像的特征提取（对边界比较敏感），从而在众多医学人工智能论文中出现。

本文在 NVIDIA TitanX GPU 上训练 1000k 个循环，大约 20 h，可以说是比较快的。然而，注意到本文的数据预处理（生成 SVF）使用了 CPU 集群，共处理 150 个数据，但每个数据在单个 CPU 核上需要 6 个小时的运算，这种代价是非常高昂的。

精度比较：



从左到右的 4 列，分别为运动图像、固定图像、本文推荐算法和 LCC 优化算法（一种非深度学习算法）。青色为变形的运动图像的预测结果，橙色为 target。可以看到文中算法在精度上有优势。

3.2 神经网络法学习形变向量场（非监督学习）

3.2.1 Cao X, Yang J, Zhang J, et al. Deformable Image Registration based on Similarity-Steered CNN Regression (MICCAI 2017)

数据:

两个小型的脑部 MR 图像数据集: LONI (40 个 MR) 与 ADNI (30 个 MR)。

除了 MRI 数据之外,这两个数据集还提供了一些解剖结构的分割,包括灰质(Gray matter, GM), 白质(White matter, WM), 等等。

介绍:

本文的方法是通过两张图(变换图像 M 与固定图像 F)来学习形变场(deformation field)。网络结构分为两部分,传播网络和学习网络。

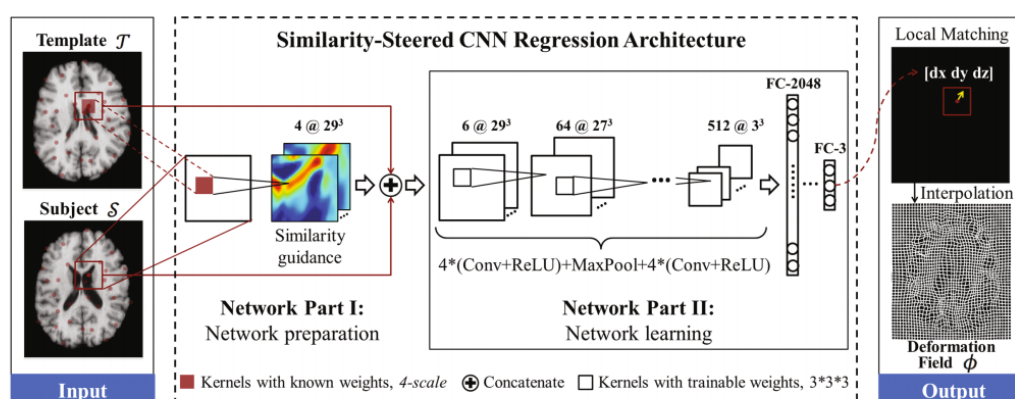


Fig. 1. The framework of the proposed similarity-steered CNN regression for deformable image registration. The input image pair has already been linearly aligned. Here, we use 2D examples for easy illustration, while our implementations are in 3D.

第一部分网络是为了提供对相似性的度量。使用多层的卷积层,作者根据固定图像和变换图像生成了类似热力图的相似性度量图(如图中彩色图像所示);同时为了消除卷积核大小这一超参数的影响,采用了4种不同大小的卷积核生成了多层的相似性度量图,并与原始图像一起输入后面的配准网络。

注意,输入网络的是一个小块(patch),而不是整个图像。同时我们可以发现,网络是使用模板图像中的patch中心部分同目标图像中的整个patch进行相似性度量的。

配准网络使用的是简单的三维卷积网络,对于采样的若干个小块采用local matching预测 dx, dy, dz 变化向量,再用B样条将各个小块没有覆盖到的区域进行插值,形成向量场。

对DICE系数(DSC)进行测量,文中方法的表现如下:

	DSC (%)		
	GM	WM	CSF
Demons	72.8 \pm 1.0	80.8 \pm 7.3	62.9 \pm 5.1
SyN	72.7 \pm 1.6	78.1 \pm 0.7	61.5 \pm 2.6
Proposed	75.3 \pm 1.4*	81.3 \pm 0.6*	61.2 \pm 2.4

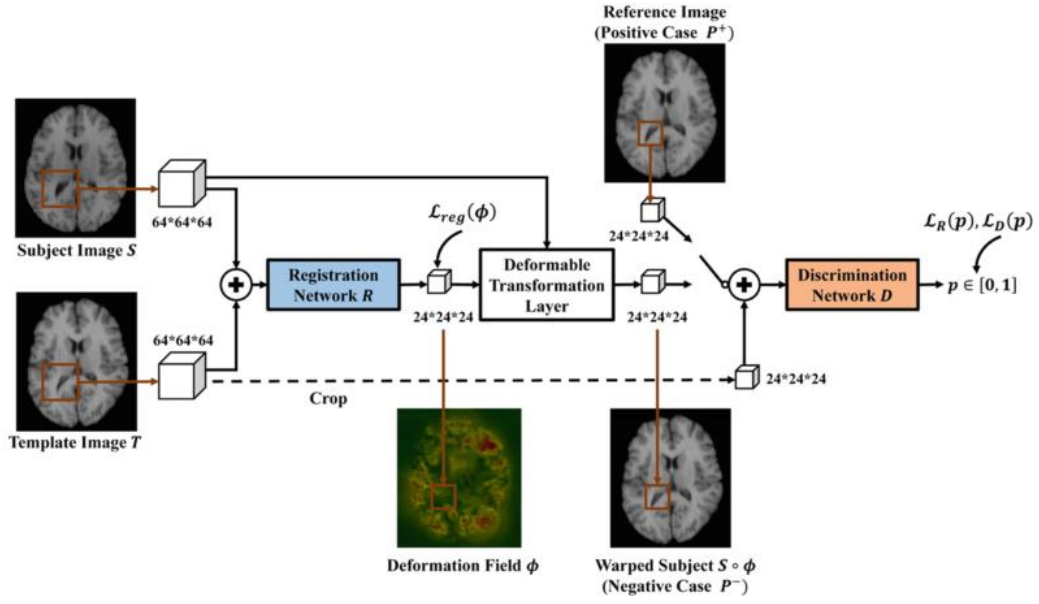
与非深度学习方法（Demons, SyN 均为非常优秀的非深度学习配准方法）相比，本文方法能够达到基本旗鼓相当的预测精度（在灰质 GM、白质 WM 等解剖结构上）。值得注意的是，本文实际上使用的非监督的学习方法，并没有人工生成向量场作为标签，可以较大的节约时间。不过，本文的配准精度很大程度上依赖于样本 patch 的选择，还有最后插值生成向量场时插值的精度。

3.2.2 Fan J, Cao X, Xue Z, et al. Adversarial Similarity Network for Evaluating Image Alignment in Deep Learning Based Registration (MICCAI 2018)

本文介绍了一种用于图像配准的无监督对抗相似网络。与现有的深度学习配准框架不同，作者的方法不需要 ground truth 变形和具体的相似性度量。作者连接 Registration 网络和 Discrimination 网络与变形的转换层。利用来自鉴别网络的反馈训练配准网络，该鉴别网络被设计成判断一对配准图像是否足够相似。使用对抗训练,配准网络被训练来预测准确到足以欺骗鉴别网络的变形。在四个脑 MRI 数据集上的实验表明，与包括基于深度学习的配准方法在内的最新配准方法相比，作者的方法在准确性和效率方面都具有前瞻性。

算法的特点如下：

1. 虽然整体网络是无监督的，但配准网络实际上是收到鉴别网络判断 P 值作为标签的监督学习。
2. 在配准网络中，输入大小为 2 个 64*64*64，而输出大小是 24*24*24，小于输入大小。这是为了适应变形(deformable)配准中的位置偏移。



网络结构与上一篇相似。



Fig. 2. The discrimination network.

我们可以看到，鉴别网络输入是配准的 patch，输出的是 P 值；实际上网络本身就代表了一种对于配准相似性的度量方法。随着训练的继续，度量方法也更加优秀。

以上面提到的 The Dice Similarity Coefficient (DSC)做度量，文中测试结果如下：

$$DSC(A, B) = \frac{2|A \cap B|}{|A| + |B|}$$

Table 1. Mean DSC (%) on LPBA40, IBSR18, CUMC12, and MGH10 datasets.

Dataset	D.Demons	SyN	Supervised by GT	Supervised by SSD	Supervised by CC	Proposed method
LPBA40	68.7 ± 2.4	71.3 ± 1.8	70.7 ± 2.3	70.4 ± 2.2	71.2 ± 2.8	71.8 ± 2.3
IBSR18	54.6 ± 2.2	57.4 ± 2.4	52.4 ± 3.1	53.1 ± 1.8	54.2 ± 3.4	57.8 ± 2.7
CUMC12	53.1 ± 3.4	54.1 ± 2.8	52.7 ± 3.1	51.6 ± 2.3	51.8 ± 4.1	54.4 ± 2.9
MGH10	60.4 ± 2.5	62.4 ± 2.4	59.7 ± 2.5	58.2 ± 1.6	59.6 ± 2.9	61.7 ± 2.1

从配准方法来看，与新型非神经网络配准方法-D.Demons 与 SyN 做对比，表现与 SyN

相近，明显优于 D.Demons。从度量方法来看，训练的鉴别网络也是优于 GT、SSD、CC(Cross correlation)等常用相似性度量的。

3.2.3 Hu Y, Gibson E, Ghavami N, et al. Adversarial Deformation Regularization for Training Image Registration Neural Networks (MICCAI 2018)

数据：

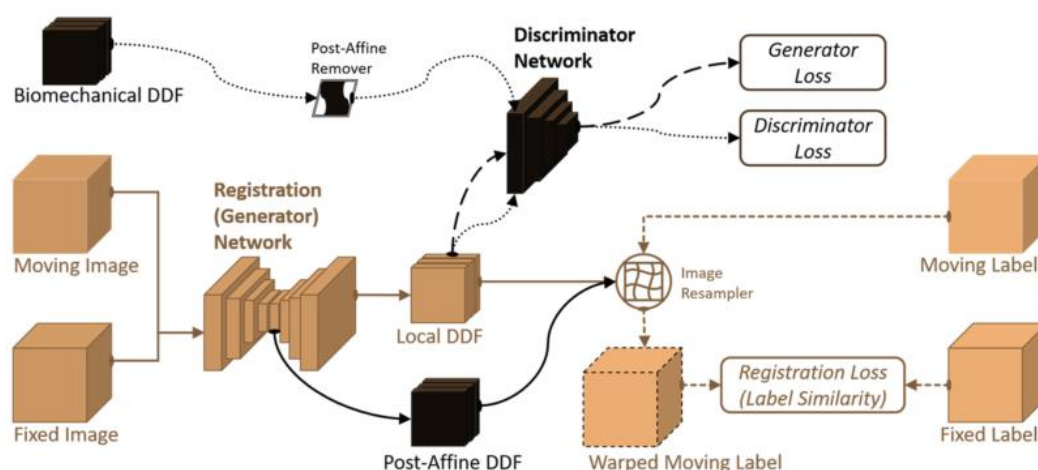
前列腺图像。从 76 个病人采集的共 108 对 MRI 图像和 三维程序内经直肠超声(TRUS) 图像。采样到 $0.8 \times 0.8 \times 0.8\text{mm}$ 后，将图像归一化到 0 均值，1 方差。

介绍：

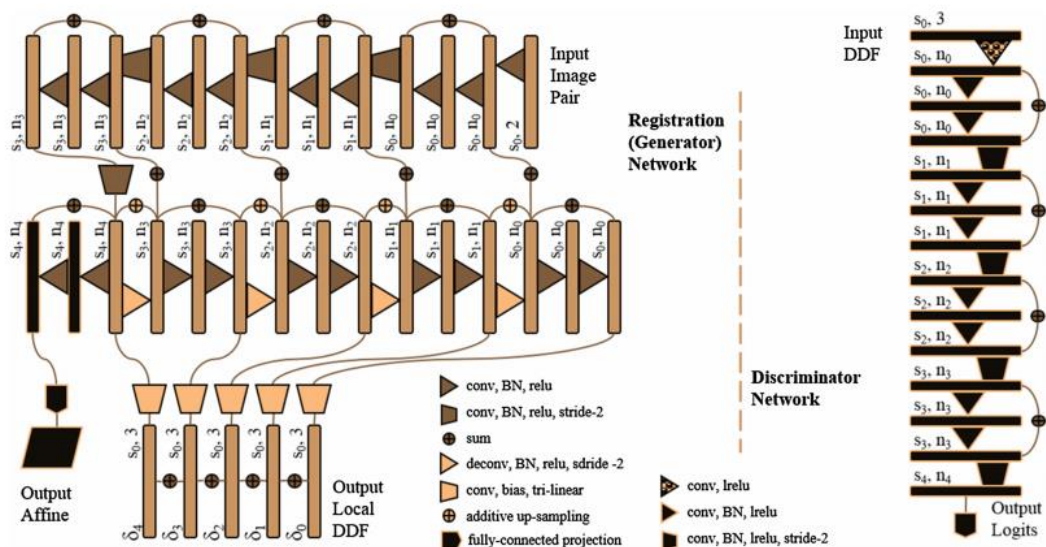
作者描述了一种对抗学习方法来约束卷积神经网络训练用于图像配准。以微创前列腺癌介入治疗为例，证明利用软件的生物力学模拟（Biomechanical）结果，可以调整解剖标签驱动的配准网络，对核磁共振（MR）和三维程序内经直肠超声（TRUS）图像进行配准。

本文的特色有几条：

- 1.异质性的配准。在 MR 与 TRUS 这样完全不同种类的数据间进行配准。
- 2.利用生物力学模拟结果对网络进行调整，相当于使用了某种先验信息。
- 3.非监督性的配准。端到端训练网络能够实现高效、全自动的配准，只需要 MR 和 TRUS 图像对作为输入，在推理过程中不需要解剖标签或模拟数据。




高亮部分为一般的弱监督配准网络；黑色部分为本文新添加的组件，左上角部分即生物力学模拟的 vector field。



上图为主网络。左边为配准网络，右边为鉴别网络。实际上，配准网络与之前网络中使用的全卷积式 U-net 的理念相同，都是有收缩、扩张两个路径，同时将收缩路径中的元素与扩张路径中的元素进行 **concat**，来同时得到粗粒度和细粒度的信息。唯一的区别是本文的收缩网络使用的是 **resnet**，扩张网络使用的是 **reverse resnet**。至于鉴别网络，它与配准网络中的收缩路径使用的是相同结构的 **resnet**。

与传统网络不同的是，可以发现主网络的左下角有一个额外的 **residual block**，来预测一个 **Affine** 变换的 12 个参数。这是因为本文的配准目标不是同质的；是在 **MR** 图像同 **TRUS** 图像之间进行配准。下图可以看到，图像相差非常大。作者认为变换分为两部分；一部分是生物学的形变，包括病人的呼吸等等带来的位移；另一部分则是系统坐标的变化，是由于 **TRUS** 探针的位置不同，图像的方向不同等等带来的，而这一部分的变换不应该使用生物力学仿真进行正则化。



TRUS 与 MR 的差异

3.3 对图谱(Atlas)的生成或应用

近些年来，基于多图谱(Atlas)的图像分割方法在实际应用中取得了很大的成功。它在原有的单幅图像配准的基础上，发展形成了利用多幅图像配准并进行标签传播的基本框架。简单地图谱就是一个模板，包括图像和图像的标签。

Atlas 方法将图像分割问题变为图像配准问题。配准问题又可以看成是最优化问题,即寻求目标图像和模板图像之间的对应变换函数的过程,其中的变换函数包括仿射变换、刚性变

换和非线性变换(非刚性变换)等。

该方法分为两个过程：(1) 配准过程，即将每一幅模板图像配准到目标图像，并相应的将模板的标签传播(propagate)到目标图像作为它的一个分割；(2) 标签融合(label fusion)过程，即将得到的所有分割以一定的方法进行组合进而得到最终的标签，可以减少多 Atlas 的传播误差。

从多个 Atlas 图像组合得到最终的目标图像的分割可以看成是一个类似 boosting 的方法。每个 Atlas 得到的分割都可以看作一个分类器，作者最终的目标就是将这些分类器组合起来形成一个更好，更鲁棒的分类器，

3.3.1 Wang H, Zhang R. Atlas Propagation Through Template Selection (MICCAI 2018)

数据：

1. 心脏 MRI 图像：42 个 case 的病人 CT 图像。每个 case 均人工画出 16 个解剖学结构，包括左右心房、左右心室等等。所有图像被重采样到有 2mm^3 的分辨率。




Fig. 2. (a) Axial (left) and coronal (right) views of one CT image with manual annotations. (b) One template image at 2, 10, and 15 mm^3 resolutions, respectively.

介绍：

Atlas 的选择也是一个比较热的研究方向。相比于组合所有 Atlas 形成的分割，选择比较好的具有先验或后验的 Atlas 能够得到更好的结果。另外 Atlas 的数量也能对最终的结果产生比较大的影响。一些实验表明 10-20 幅 Atlas 是一个比较好的选择。(Aljabar et al. 2009)

基于模板的 Atlas 传播可以减少多 Atlas 分割中的配准代价。在这种方法中，图集和测试图像被配准到一个共同的模板。作者表明，使用一个共同的模板以减少 Atlas 传播误差,可能是次优的；相反，本文建议通过采用大型模板库和快速模板选择来为每个测试图像应用自定义选择的模板技术。所提出的方法明显优于普通模板 Atlas 传播。使用 50 个图像的模板库，作者的方法得到的结果与标准直接配准的多图集分割结果相当，配准代价很小。

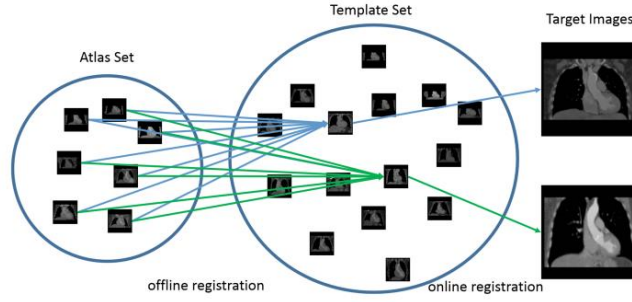



Fig. 1. Atlas propagation through a single selected template.

图：基于单模板的 Atlas 传播（分割）。

本文的创新点在于采用的是模板选择(Template selection)，而不是 Atlas 选择。下面是基于模板的 Atlas 传播对于误差的估计界：

$$\sum_{i=1}^n F(A_i, T, K) \leq \sum_{i=1}^n F(A_i, T) + nF(T, K)$$

右侧的两项误差，前面是模板对所有 Atlas 的误差；后面是模板对目标图像的误差。显然 minimize 模板对目标图像的误差比减少对所有 Atlas 的误差更为容易，因此应用模板选择方法是可行的方法。作者假设，如果有一个合适大小的模板库，那么对于每个目标图像都有较大概率可以找到一个比较相似的模板图像。



上图是实验结果。左侧是选择不同数量 Atlas 对 DICE 精度的影响；右侧是不同数量模板对 DICE 精度的影响。

实际上，本文是一个证明性实验，证明 Atlas selection 与 Template selection 都能在与 Atlas 进行配准时提高表现。

3.4 其他算法

3.4.1 Q-learning


Ma K, Wang J, Singh V, et al. Multimodal Image Registration with Deep Context Reinforcement Learning (MICCAI 2017)

数据：

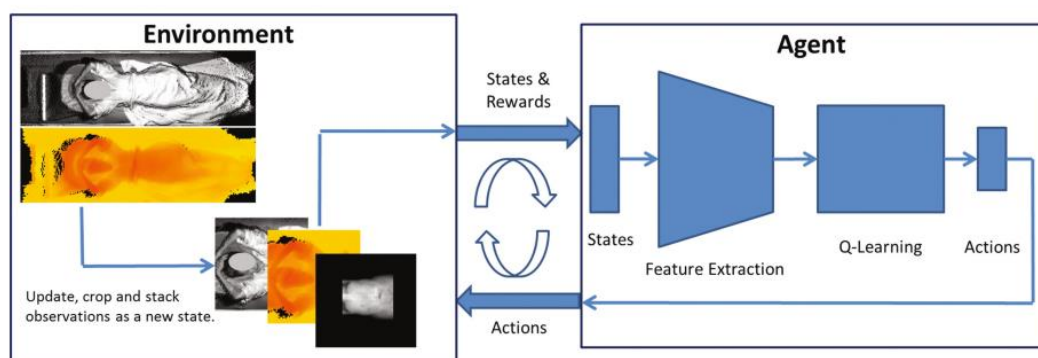
来源：胸部和腹部/骨盆扫描。最终在多个位点上共取得 1788 个深度 CT（注，深度 CT 是使用深度相机生成的数据，与普通 CT 不同）。同时，在训练数据中添加了随机扰动避免过拟合。

介绍：

使用深度相机/深度 CT 技术可以更好的查看病人状况。不过，要利用深度相机的信息，就需要将深度相机数据和普通 CT 进行配准。本文将深度学习和强化学习结合，利用深度 Q 学习的改进算法进行处理。



在 Q 学习中，机器人实际上在模仿专家的配准过程，移动投影的大小、位置尝试与深度图像进行贴合，并进行代价估计。



实际上，本文的策略对于 Q 学习来说非常简单，可以说相当于一枚棋子只有向上、下、左、右四个方向行走；代价函数也非常简单，就是当前 MR 图像与深度 CT 图像重叠部分的

相似度。只要有合适的数据，该算法不难实现。

本文在 MICCAI 2017-18 的医学图像配准方法之中是绝无仅有的。它给我们提供了一种全新的思路，即让计算机模仿人类专家配准的过程来进行配准，而不是通过预测向量场或迭代法等人工难以完成的方法进行配准。

3.4.2.数据生成方法

Uzunova H, Wilms M, Handels H, et al. Training CNNs for Image Registration from Few Samples with Model-based Data Augmentation (MICCAI 2017)

数据：

1. 脑部 MRI 图像：预先配准的 40 个病人的图像，数据集为 LPBA40 数据集。对于每个二维图，在大脑边界上取 100 个 landmark，在内部取 12 个 landmark。评价指标为 20 个脑部结构的 Jaccard 系数平均值。

2. 心脏 MRI 图像：提取舒张末期中室短轴片(end-diastolic mid-ventricular short-axis slices)，在左心室外膜、左右心室内膜共取 104 个 landmark。评价指标是计算左心室外膜和左右心室内膜轮廓的平均对称轮廓距离。

介绍：

本文解决的是 CNN 在配准中训练数据不足的问题，给出一种数据增强方法。为了使用非医学图像配准中使用的 FlowNet 结构（需要 22000 pairs 图像+dense ground truth 训练）

增强方法：是 Model-based 方法。从训练数据中学习一个统计表现模型（statistical appearance model, SAM），并应用该模型合成任意数量的数据。传统 SAM 的模型空间维度受训练数据数量的限制：本文使用利用局部相关性改进的 SAM 解决了该问题。

实验用三种方法进行对比：

FlowNet-Reg: 微分同胚变分法进行配准。

FlowNet-Random: 稠密光滑随机变形（Dense smooth random deformations）+ 光滑局部亮度改变 该方法为 U-net 的增强方法

FlowNet-SAM: 本文的方法。

models. Note the different number of training samples (2nd, 4th column). Superscripts indicate statistically significant differences to FlowNet SAM ($\diamond: p < 0.01$, $\star: p < 0.001$).

Method	Brains (Jaccard)		Cardiac (contour dist.)	
	# train	mean(\pm std)	# train	mean(\pm std)
Before reg		0.460 \pm 0.063 \star		6.163 \pm 2.472 \star
VarReg (training data)		0.563 \pm 0.053		2.250 \pm 0.755
VarReg (test data)		0.562 \pm 0.051 \diamond		3.437 \pm 2.427 \star
FlowNet (pre-trained)	22232	0.507 \pm 0.053 \star	22232	8.171 \pm 6.981 \star
FlowNet-Reg	945	0.547 \pm 0.049 \star	600	3.053 \pm 0.910 \star
FlowNet-Random	9698	0.505 \pm 0.077 \star	9698	7.785 \pm 5.430 \star
FlowNet-SAM	9572	0.568 \pm 0.042	9572	2.670 \pm 0.930

从上表可以看出，本文方法在使用较少数据（只有 945/9698/9572）时，就可以达到原始 FlowNet 需要 22000 pairs 图像的效果。这在医学图像中是非常令人可喜的事情，因为医学图像的“金标准”只有医生，要想获得大量有标注的图像，只能让医生通过手动或半自动方法进行操作。医生的时间十分宝贵，因此医学图像的标注数据也非常珍贵。如果能够使用较少数据达到较好效果，无疑对人力物力都是极大的节省。

3.4.3.线性规划加速法

Kybic J, Borovec J. Fast Registration by Boundary Sampling and Linear Programming (MICCAI 2018)

介绍：

当速度比精度更重要时，作者解决图像配准的问题。作者提出了一系列的简化和近似适用于几乎任何像素的图像相似性准则。作者首先在垂直于图像边缘的方向上的一组稀疏关键点处采样图像，然后创建单个贡献的分段线性凸近似。作者得到一个线性规划方程，可以通过标准算法很快地找到全局最优。线性规划公式还允许容易地添加正则化和信赖域边界。作者已经测试了仿射和 B 样条变换表示的方法，理论上可以使用任何线性模型。较大的变形可以用 multi-resolution 的方法来处理。作者表明，作者的方法比基于像素的配准快得多，只有一个小的精度损失。与基于标准关键点的配准相比，即使不能可靠地识别和匹配单个关键点，作者的方法也是适用的。

这里我们只简单介绍其思想。作者将配准的损失函数化为以下线性规划问题：

$$\min \left[\sum_{i=1}^M D_i + \gamma \sum_{(j,k) \in \mathcal{N}} r_{jk} + \lambda \sum_{j=1}^N s_j \right]$$

约束为

$$c_j - c_k \leq r_{jk}, \quad c_j - c_k \leq r_{jk}, \quad c_j \leq s_j, \quad -c_j \leq s_j$$

其中 D_i, c_j, r_{jk}, S_j 是四组变量，代表配准中的不同损失、正则项等等。可以使用单纯型法求解。

4. 总结

从近两年的 MICCAI 论文来看，关于医学图像配准方法的论文主要还是神经网络学习形变向量场的方法居多。而神经网络学习形变向量场从 2017 年以监督学习为主，变为 2018 年以非监督学习为主。

监督学习方法主要是用于解决之前使用传统方法进行配准时，需要多次、长时的迭代的问题；然而监督学习方法需要针对配准训练样本生成 Vector Field，这样的预处理仍然是代价非常大的，这些方法只能减少训练完成后的配准。

这几篇文章中的非监督学习方法实际上是一种“lazy”方法，不需要任何的额外信息，只需要输入需要配准的两幅图像即可输出 deformation field、moved image 等等所有需要的信息。这是全卷积网络这种端到端网络的广泛应用造成的。

Atlas 方法实际上是一种传统的模板匹配方法。Atlas 是医院使用众多脑部 MRI 图像合成的标准脑部图像，将新的病人的脑部 MRI 与 Atlas 进行配准即可；MICCAI17-18 年关于这部分的文章主要是介绍新型的 Atlas 生成方法，还有 Atlas 的新型应用。

此外我们也可以看到一些特别的例子。如针对数据过少的数据生成方法，还有用精度换速度的线性规划方法，甚至使用强化学习中的 Q 学习进行模拟人工图像对齐的方法。它们实际上可以帮助解决很多特殊情况的问题。比如某些医学图像，如胰腺的标注非常复杂，数据稀少；或者病人的身体条件不容乐观，必须进行快速的诊治，等等。这些方法如果与其他方法进行结合，有望成为非常优秀的应用方法。

3. 下周工作计划

对新数据进行训练。

搭建 PDE-net 网络。

注：本周为考试周，可能需要考试完毕之后再进行工作。

附表：工作整理

任务类型	任务内容	截止日期	当前进度
------	------	------	------

工作	肝脏分割比赛 （浙一举办） 负责 registraion 部分	结束	对肝脏配准继续进行研究、调整。
工作	神经纤维瘤研究 （中期目标）		蔡老师提出新方法：使用偏微分方程网络 PDE-net 对 level set 进行改进。正在学习相关内容。

本周工作时长：8 小时*5+ 3 小时*2 = 46 小时。